

Apprentissage non supervisé

Françoise Fessant
TECH/SUSI

28/09/2006



recherche & développement



Introduction (1)

- Apprentissage non supervisé
 - Consiste à inférer des connaissances sur les données
 - Sur la seule base des échantillons d'apprentissage,
 - Pas de cible, recherche de structures naturelles dans les données

- Différentes tâches sont associées à l'apprentissage non supervisé
 - Clustering (segmentation, regroupement) : construire des classes automatiquement en fonction des exemples disponibles
 - L'apprentissage non supervisé est très souvent synonyme de clustering
 - Règles d'association : analyser les relations entre les variables ou détecter des associations
 - Réduction de dimensions

Introduction (1)

- Apprentissage non supervisé
 - Consiste à inférer des connaissances sur les données
 - Sur la seule base des échantillons d'apprentissage,
 - Pas de cible, recherche de structures naturelles dans les données
- Différentes tâches sont associées à l'apprentissage non supervisé
 - **Clustering** (segmentation, regroupement) : construire des classes automatiquement en fonction des exemples disponibles
 - L'apprentissage non supervisé est très souvent synonyme de clustering
 - **Règles d'association** : analyser les relations entre les variables ou détecter des associations
 - Réduction de dimensions

Introduction (2)

- Quelques bonnes raisons de s'intéresser à l'apprentissage non supervisé
 - Profusion d'enregistrements et de variables
 - Constituer des échantillons d'apprentissage étiquetés peut être très coûteux
 - Découvertes sur la structure et la nature des données à travers l'analyse exploratoire
 - Utile pour l'étude de caractéristiques pertinentes
 - Prétraitement avant l'application d'une autre technique de fouille de données
- On obtient des modèles descriptifs qui permettent mieux connaître ses données, de découvrir des informations cachées dans la masse des données

Clustering

- Les techniques de clustering cherchent à décomposer un ensemble d'individus en plusieurs sous ensembles les plus homogènes possibles
 - On ne connaît pas la classe des exemples (nombre, forme, taille)
- Les méthodes sont très nombreuses, typologies généralement employées pour les distinguer
 - Méthodes de partitionnement / Méthodes hiérarchiques
 - Avec recouvrement / sans recouvrement
 - Autre : incrémental / non incrémental
- D'éventuelles informations sur les classes ou d'autres informations sur les données n'ont pas d'influence sur la formation des clusters, seulement sur leur interprétation

Clustering

- Les techniques de clustering cherchent à décomposer un ensemble d'individus en plusieurs sous ensembles les plus homogènes possibles
 - On ne connaît pas la classe des exemples (nombre, forme, taille)
- Les méthodes sont très nombreuses, typologies généralement employées pour les distinguer
 - Méthodes de partitionnement / Méthodes hiérarchiques
 - Avec recouvrement / sans recouvrement
 - Autre : incrémental / non incrémental
- D'éventuelles informations sur les classes ou d'autres informations sur les données n'ont pas d'influence sur la formation des clusters, seulement sur leur interprétation

Similarité

- On cherche à maximiser la similarité intra-classe et à minimiser la similarité inter-classe
- Le point clé est le critère de similarité (fonction de distance)
- La notion de similarité est fonction du type des données
 - Variables définies sur une échelle d'intervalles, binaire, nominale, ordinale, ...

- Exemples de distances

- Distance euclidienne pour les variables continues $d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$
- Coefficient de concordance pour les variables binaires
 - À partir de la table de contingence des variables

		x	
		1	0
y	1	a	b
	0	c	d

$$d(x, y) = \frac{b + c}{a + b + c + d}$$

- Et bien d'autres mesures possibles

La méthode de clustering "idéale" (1)

- Prise en compte de données de différents types : symbolique, numérique, matrice de similarité, données mixtes
 - Comment comparer des objets caractérisés à la fois par des attributs numériques et symboliques
- Formes arbitraire des clusters
 - De nombreuses méthodes favorisent la découverte de formes sphériques
- Minimisation du nombre de paramètres à fixer
 - Avec certaines méthodes, il est nécessaire de préciser le nombre de classes recherchées
- Insensibilité à l'ordre de présentation des exemples
 - Certaines méthodes ne génèrent pas les mêmes classes si l'ordre de parcours des données est modifié

La méthode de clustering "idéale" (2)

- Résistance au bruit et aux anomalies
 - La recherche des points isolés (outliers) est un sujet de recherche en soi
- Problème en grande dimensions
 - Certaines méthodes ne sont applicables que si les objets ou individus sont décrits sur deux ou trois dimensions
 - Construction et interprétation de clusters en grande dimension
- Passage à l'échelle
 - Certaines méthodes ne sont pas applicables sur de gros volumes de données
- Interprétation et utilisation des résultats
 - Les utilisateurs doivent pouvoir donner un sens aux classes découvertes
 - Comment un utilisateur peut-il influencer un processus de catégorisation en introduisant des contraintes

Méthodes de partitionnement

- Construire une partition en classes d'un ensemble d'objets ou d'individus

- Principe
 - Création d'une partition initiale de K classes,
 - Puis itération d'un processus qui optimise le partitionnement en déplaçant les objets d'une classe à l'autre

- Solutions
 - Méthode exacte
 - Par évaluation de toutes les partitions possibles

 - Méthodes approchées/heuristiques
 - K-moyennes (centres mobiles) : une classe est représentée par son centre de gravité
 - K-medoids : une classe est représentée par son élément le plus représentatif

K-moyennes (1)

■ Principe

- Une classe est représentée par son centre de gravité,
- Un objet appartient à la classe dont le centre de gravité lui est le plus proche



■ Algorithme

- Fixer le nombre de classes a priori K
- Initialiser aléatoirement les centres (K individus tirés au hasard comme représentants des classes)
- Affecter chaque observation à la classe qui minimise la distance entre le centre et l'observation (centre le plus proche)
- Recalculer les nouveaux vecteurs centres (la moyenne)
- Itérer l'opération jusqu'à la stabilité

- Le critère de similarité est l'erreur quadratique entre un exemple et son centre

■ C'est un algorithme très utilisé

K-moyennes (2)





Choix des centres initiaux
au hasard

Affectation des classes

Recalcul des centres

Réaffectation des classes



K-moyennes (3)

■ Points forts

- Simple à implémenter et à comprendre
- Passage à l'échelle
 - Complexité en $O(T.K.N)$ où T est le nombre d'itérations et N le nombre d'exemples
 - En général K et T sont nettement inférieurs à N

■ Difficultés

- Nécessite de spécifier le nombre de classes à l'avance
- Utilisable seulement quand la notion de moyenne existe (donc pas sur des données nominales)
- L'algorithme peut rester bloqué sur un optimum local
- Sensible au bruit et aux anomalies
- Sensibilité aux conditions d'initialisation (on n'obtiendra pas forcément les mêmes classes avec des partitionnements initiaux différents)
- Ne permet pas de définir des classes aux formes non convexes

K-moyennes, variantes

■ K-medoids

- Même principe que les K-moyennes, on utilise à la place de la moyenne le medoid
- Un medoid est l'objet le plus central dans la classe
- moins sensible au bruit et aux points isolés, mais plus couteux en calculs
- Algorithme PAM (Partitioning around medoids)
- CLARA (Clustering Large Applications), adapté aux grands ensembles d'apprentissage

■ Version floue de l'algorithme des K-moyennes

- Recouvrement possible des classes

■ Clustering à base de modèle en utilisant les mixtures de gaussiennes

- La valeur de K correspond au nombre de composantes de la mixture
- Apprentissage avec l'algorithme EM : un objet est affecté à une classe selon un poids qui représente sa probabilité d'appartenance à la classe
- Autorise des formes plus flexibles pour les clusters

Méthodes hiérarchiques (1)

- Les clusters sont organisés sous la forme d'une structure d'arbre

- Deux familles d'approches hiérarchiques
 - Approche ascendante (ou agglomération)
 - Commence avec un objet dans chaque classe,
 - Puis fusionne successivement les 2 classes les plus proches
 - S'arrête quand il n'y a plus qu'une classe contenant tous les exemples

 - Approche descendante (ou par division)
 - Tous les objets sont initialement dans la même classe
 - Puis division de la classe en sous classes jusqu'à ce qu'il y ait suffisamment de niveaux ou que les classes ne contiennent plus qu'un seul exemple

- Le nombre de clusters n'a pas à être prédéfini


Méthodes hiérarchiques (2)

- Choix d'un critère de distance entre les clusters et d'une stratégie pour l'agrégation/la division

- Les mesures de distance sont nombreuses
 - Lien simple : distance des deux objets les plus proches des clusters,
 - Tendance à former des chaînes
 - Lien complet : distance des deux objets les plus éloignés dans les deux clusters,
 - Bonne méthode pour les grappes, mais sensible aux anomalies
 - Lien des moyennes : la distance entre deux objets est donnée par la distance des centres
 - Faible résistance aux anomalies
 - Lien moyen: distance moyenne de toutes les distances entre un membre d'un cluster et un membre de l'autre
 - Plus difficile à calculer

Méthodes hiérarchiques (4)

- Complexité
 - Tous les algorithmes sont au moins en $O(N^2)$ avec N le nombre d'exemples
- Le résultat de la classification hiérarchique est un arbre de classes représentant les relations d'inclusion entre classes (dendrogramme)
- Une classification particulière s'obtient en coupant l'arbre des classes à un niveau donné.



Méthodes hiérarchiques (5)

■ Intérêt

- Facile à implémenter
- Fournit une structure (préférable pour une analyse détaillée qu'une méthode de partitionnement)

■ Difficultés

- Passage à l'échelle difficile
 - Complexité en $O(N^2)$
- Pas de remise en question possible des divisions ou agglomérations
 - Deux classes agglomérées à un niveau ne peuvent pas être séparées à un autre niveau

■ Recherches en cours

- Intégration des méthodes hiérarchiques avec d'autres méthodes
 - BIRCH (1996) : basée sur la représentation d'une classe par ses traits caractéristiques
 - CHAMELEON (1999) : basée sur la théorie des graphes et une représentation plus riche des données

Méthodes à base de densité

■ Principe de base

- Utilisation de la densité à la place de la distance
- Les clusters sont des régions de l'espace qui ont une grande densité de points
 - Un point est dense si le nombre de ses voisins dépasse un certain seuil
 - Un point est voisin d'un autre point s'il est à une distance inférieure à une valeur fixée

■ Caractéristiques des méthodes

- Découvre des classes de formes quelconques
- Peu sensible à la présence de bruit ou de points isolés
- Nécessite seulement un parcours des données
- Ne nécessite pas de prédéfinir un nombre de classes

■ Différents algorithmes

- DBSCAN (1996), OPTICS (1999), DENCLUE (1998), CLIQUE (1998)

Méthodes à base de grille

■ Principe

- Méthode basée sur le découpage de l'espace des exemples suivant une grille
- Après initialisation, toutes les opérations de clustering sont réalisées sur les cellules, plutôt que sur les données
- Construction des classes en rassemblant les cellules voisines en terme de distance

■ Différents algorithmes

- STING (a S**T**atistical Information Grid approach (1997)
- WaveCluster (utilise la notion d'ondelettes) (1998)

Conclusion sur le clustering (1)

- Les méthodes sont nombreuses
 - Toutes sont basées sur une mesure de distance ou similarité entre classes
- Différentes classes de méthodes
 - Partitionnement, hiérarchique, ...
- Choix du meilleur algorithme ?
 - Chaque algorithme a ses limites et fonctionne pour un certain type de données
 - La qualité du résultat de clustering dépend des connaissances a priori de l'utilisateur, de l'algorithme, de la fonction de distance, de l'application ...

Conclusion sur le clustering (2)

- Évaluation d'un résultat de clustering
 - La qualité d'un clustering est difficile à évaluer : les "bons clusters" ne sont pas connus
 - Critères d'évaluation
 - Jugement d'un expert ou évaluation par un utilisateur
 - Utiliser des données étiquetées si elles existent
 - Comparaison avec une segmentation de référence
 - Autres critères : indices divers reposant généralement sur des rapports de distances intra / extra clusters

- Recherches en cours
 - Passage à l'échelle pour traiter de gros volumes de données
 - Prise en compte de contraintes ou connaissances a priori sur les données pour optimiser la construction des classes
 - Méthodes interactives permettant de prendre en compte les besoins des utilisateurs

Découverte de règles d'association (1)

- Identifier les items qui apparaissent souvent ensemble lors d'un évènement (découverte des corrélations entre attributs)
- Règles : Implications du type si X alors Y ou (X->Y)
 - Exemple analyse des ventes : produits fréquemment achetés ensemble {pain, beurre} -> {lait}


caddie	liste des items achetés
1	{pain, beurre, lait}
2	{pain, viande}
...	
n	{fruit, poisson,pain}

- Les attributs à inclure dans la relation sont inconnus
- Deux critères d'évaluation : support et confiance
 - Support (fréquence) : % d'observations qui contiennent tous les éléments de la règle



Découverte de règles d'association (2)

- Deux critères d'évaluation : support et confiance
 - Confiance (précision/fiabilité) : % d'observations présentant Y sachant qu'ils ont X



- Deux mesures d'intérêt dont le niveau est défini par l'utilisateur
- Seules les règles qui ont un certains support et une certaine valeur de confiance sont intéressantes
- La plupart des approches utilisent des algorithmes basés sur le principe de la détection des ensembles d'items fréquents

Algorithmes (1)

- Algorithme fondateur : APriori (1994), se décompose en 2 étapes
 - Recherche des sous ensembles fréquents (support)
 - Un ensemble fréquent est un ensemble d'items dont la fréquence d'apparition dépasse un certain seuil
 - Recherche des règles d'association (confiance) à partir des sous ensembles retenus

Etape1

3 transactions

n°	items
1	A, B, C
2	A, B, D
3	B, D, E

Taille 1

itemset	support
A	2
B	3
C	1
D	2
E	1

Taille 2

itemset	support
A, B	2
A, D	1
B, D	2

Taille 3

itemset	support
A, B, D	1

Etape2

règles	confiance
A -> B	2/2=100%
B -> A	2/3=66%
B-> D	2/3=66%
D->B	2/2=100%

Critères : support >40% et
Confiance > 70%

Algorithmes (2)

- A Priori très simple, mais des limites
 - Le nombre de lectures de la base est important : on commence par lister tous les ensembles de 1 items fréquents, puis tous les ensembles de 2-items fréquents, ...
 - Problèmes de mémoire : c'est couteux de générer des ensembles d'items avec beaucoup d'items

- Améliorations : différentes optimisations proposées
 - Génération plus efficace des règles à partir des ensembles d'items
 - Optimisation de la recherche des sous ensembles fréquents
 - FPTree (2004) : détermine les ensembles fréquents sans générer les candidats
 - Représentation condensée de la base sous la forme d'un arbre

Algorithmes (3)

- Différents indices permettent de mesurer la pertinence d'une règle
 - Mesures objectives
 - Support et confiance
 - Mesures subjectives
 - Une règle est intéressante si elle est inattendue et/ou actionnable (si l'utilisateur peut faire quelque chose avec)
 - Le choix d'un indice dépend des points à mettre en évidence et des données
 - Exemple du lift (ou amélioration/ intérêt) : $lift(A \Rightarrow C) = \frac{P(A \cap C)}{P(A)P(C)}$
 - Les transactions contenant A et C sont elles plus nombreuses que si l'achat de A et l'achat de C étaient indépendants

- Extensions
 - Transactions séquentielles
 - Quels sont les produits fréquemment achetés ensembles et successivement ?

Conclusion

- L'apprentissage non supervisé permet d'inférer des connaissances à partir d'échantillons non étiquetés
 - C'est très utile en pratique
- Il existe de nombreuses méthodes et il n'y en a pas une meilleure que les autres
- On choisit la méthode en fonction
 - Du problème et de ses a priori
 - Des données (continues, incomplètes, manquantes, volumineuses, denses)
 - De la tâche à réaliser
 - Du temps de calcul dont on dispose
- De quoi n'a-t-on pas parlé ?
 - Clustering flou, clustering spectral, clustering basé sur les graphes, co-clustering ...